

思维作业脑电的 IMF 能量熵特征提取与分类研究

李 莹^{1,2}, 艾玲梅¹, 马 苗¹

LI Ying^{1,2}, AI Ling-mei¹, MA Miao¹

1. 陕西师范大学 计算机科学学院, 西安 710062

2. 淮南师范学院 计算机与信息工程系, 安徽 淮南 232038

1. College of Computer Science, Shaanxi Normal University, Xi'an 710062, China

2. Department of Computer and Information Engineering, Huainan Normal University, Huainan, Anhui 232038, China

E-mail: almsac@yahoo.com.cn

LI Ying, AI Ling-mei, MA Miao. Feature extraction and classification study with energy entropy of IMFs to different mental tasks in EEG. *Computer Engineering and Applications*, 2009, 45(28): 128-130.

Abstract: A new feature extraction and selection method based on the energy entropy of Intrinsic Mode Functions (IMFs) is presented. Three types of different mental tasks in EEG signals radiated from the targets are decomposed into their respective IMFs using the Empirical Mode Decomposition (EMD) procedure, and the energies of the same IMF of three types of signals are different. The energy entropies of the IMFs are calculated. K -neighbor classifier is used for classification experiments for three types of signals. The results show that the correct identification ratio of experiments above 75%.

Key words: Intrinsic Mode Function (IMF); EEG; Empirical Mode Decomposition (EMD); feature extraction; K Nearest Neighbors (KNN)

摘 要: 提出了一种基于固有模态函数 (Intrinsic Mode Function, IMF) 能量熵的特征提取方法。对三类脑电思维信号分别进行了经验模态分解 (Empirical Mode Decomposition, EMD), 并得到与其相对应的 IMF。试验发现对于不同类别的信号, 同阶的 IMF 能量的判别熵有明显的不同。而采用 K -近邻分类器对三类脑电信号进行了分类, 发现基于最佳特征向量选择的分类试验的平均正确识别率达 75% 以上。

关键词: 固有模态函数; 脑电信号; 经验模态分解; 特征提取; K -近邻分类器

DOI: 10.3778/j.issn.1002-8331.2009.28.038 文章编号: 1002-8331(2009)28-0128-03 文献标识码: A 中图分类号: TP391

1 引言

脑电信号特征提取与分类是脑电信号处理中的重要环节。由于大多数实际信号是非平稳的随机信号, 使得针对非平稳信号处理的时频分析方法得到了广泛应用。Hilbert-Huang 变换是最新发展起来的处理非线性、非平稳信号的时频分析方法^[1-4]。它包括经验模态分解 (EMD) 和 Hilbert 变换两步。通过对信号的经验模态分解 (EMD) 获得一系列表征信号特征时间尺度的固有模态函数 (IMF), 然后利用 Hilbert 变换和瞬时频率求解获得信号的时频 Hilbert 谱。

EMD 是根据信号本身的尺度特征来对信号进行分解, 信号的非线性和非平稳特征可以在各阶 IMF 分量中充分保留下来, 因此, 将研究基于 IMF 分量的特征提取方法, 并通过分类试验结果, 检验该方法在不同思维作业脑电信号特征提取与分类中的正确性和有效性。首先分析一导脑电信号 EMD 分解后 IMF 分量的特点, 然后介绍基于 IMF 分量的能量的特征提取与

选择方法, 最后给出对实际信号的分类结果及其分析。

2 经验模态分解 (EMD) 方法及 K 近邻分类器简介

2.1 经验模态分解 (EMD) 方法

作为一种新的信号处理方法, EMD 方法从本质上讲是对一个信号进行平稳化处理, 其结果是将信号中不同尺度的波动或趋势逐级分解开来, 产生一系列具有不同特征尺度的数据信号, 每一个信号代表一个本征模式函数 IMF。在进行 EMD 分解时, 所获得的 IMF 必须满足下列两个条件:

(1) 对于该分量信号, 其极值点和过零点数目必须相等或至多相差一点;

(2) 在任意点, 由局部极大点和极小点构成的两条包络线的平均值为零。

EMD 分解过程也称筛选过程, 该过程描述如下:

(1) 设给定信号为 $x(t)$, 找到 $x(t)$ 所有的局部极大值并且

基金项目: 国家自然科学基金 (the National Natural Science Foundation of China under Grant No.60803088); 陕西师范大学校级资助项目 (No. 200802019)。

作者简介: 李莹 (1983-), 女, 助教, 主要研究领域为智能信息处理和模式识别; 艾玲梅 (1965-), 女, 博士, 副教授, 研究生导师, 主要研究领域为生物医学信号处理; 马苗 (1977-), 女, 博士后, 副教授。

收稿日期: 2009-03-24 **修回日期:** 2009-05-25

用三次样条函数插值连接获得上包络线,同样的方法连接局部极小值点作为下包络线,由上下包络的平均值组成均值信号 m 。并定义信号 $h=x(t)-m$ 。

(2)检查信号 h 是否满足 IMF 的基本条件或者满足给定的阈值,若满足则执行下一步;否则,对信号 h 继续执行步骤(1)。

(3)令 $c_i=h$,则 h 即为分解得到的第 i 个 IMF 分量 c_i ;并令 $r_i=r_{i-1}-c_i$ 。

(4)检查是否满足分解停止条件,若满足则执行步骤下一步;否则令 $x(t)=r_i$,返回(1), $i=i+1$ 。

(5)分解完成,得到基本模式分量 c_1, c_2, c_3, \dots , 及残留分量 r_n 。最终原信号被分解 n 个本征模式分量和一个残差:

$$x(t)=\sum_{i=1}^n c_i+r_n \quad (1)$$

式中 c_i 就是从原始信号中获得的本征模式分量, r_n 为趋势项, $c_1 \sim c_n$ 就是原数据信号经分离后得到的不同尺度信息, c_n 中应包含原始信号中最短的周期分量,即信号尺度最小的部分, r_n 中包含信号中较大尺度的部分。因为尺度越来越大,所以 r_n 是一个相对缓变的信息,最终可能是一个单调函数,也可能是一个恒量。

2.2 K 近邻分类器

KNN(K Nearest Neighbors, KNN)是一种常用的基于距离度量的分类方法。它假设整个训练集不仅包含数据集,而且包含每个元组期望的类别标签。当对一个新元组进行分类时,必须首先确定它与训练集中的每个元组之间的距离。然后进一步考虑训练集中 k 个与新元组相距最近的元组。新元组将被分配到一个类中,这个类包含了 k 个最近元组中的最多的元组。

直观地理解,所谓的 K 近邻(KNN),即分类时选出 x 的 k 个最近邻,看这 k 个近邻中的多数属于哪一类,就把 x 分到哪一类。定义判别函数为 $g_i(x)=k_i, i=1, 2, \dots, c$, 其中 k_i 表示 k 个最近邻中属于 w_i 类的样本数,决策规则为:若 $g_j(x)=\max_i k_i$, 则决策 $x \in w_j$ 。理论证明, K 近邻分类有错误率 $P^* \leq P \leq 2P^*$ 。由上式可知, K 近邻法错误率在贝叶斯错误率 P^* 和两倍贝叶斯错误率 $2P^*$ 之间。正是近邻法的这种优良性质,使它成为模式识别的重要方法。但近邻法需要将所有样本存入计算机,每次决策都要计算待识别样本与全部训练样本 $x_i^k (i=1, 2, \dots, c, k=1, 2, \dots, N_i)$ 之间的距离并进行比较,存储量和计算量都很大。

KNN 算法必须明确两个基本的因素:最近样本的数目(K)和距离的尺度。在 K 近邻分类器中,一个重要的参数是 K 值的选择, K 一般是大于 1 的一个整数,表示选择参照案例的数目。 K 值选择过小,不能充分体现待分类样本的特点,而如果 K 值选择过大,则一些和待分类样本实际上并不相似的样本亦被包含进来,造成噪声增加而导致分类效果的降低。

3 基于 IMF 的特征提取与选择

使用 Colorado 州立大学 EEG 研究中心提供的脑电思维作业数据。实验过程为:受试者坐在隔音的光线微弱的房间内,头戴电极帽,按指示完成一定的思维作业,记录相应的脑电信号,采样时间约为 10 s,采样频率为 250 Hz。电极按国标 10~20 系统标准安放于 C3, C4, P3, P4, O1, O2 共 6 导,模拟滤波范围是 0.1~100 Hz。

思维作业方式在 Keim 和 Aunon^[5] 的论文中有详细说明,共有 5 种思维作业。由于篇幅所限,取实验者 1(一位 48 岁的男

大学教师)所做的 3 种思维作业(想象几何图形旋转(rotation task),静息状态(baseline),心算乘法(multiplication))中 6 导信号和同步测得的眼电信号作为测试的数据。原始的 EEG 混有同步测得的 EOG 信号,因此分别使用快速独立分量方法^[6]对 3 种思维作业脑电信号中的眼电伪迹进行消除,消除眼电后的脑电信号及其频谱图(归一化幅度)为图 1 所示。

考虑三类目标信号,其样本数据的频谱如图 1 所示(数据长度 2 500)。

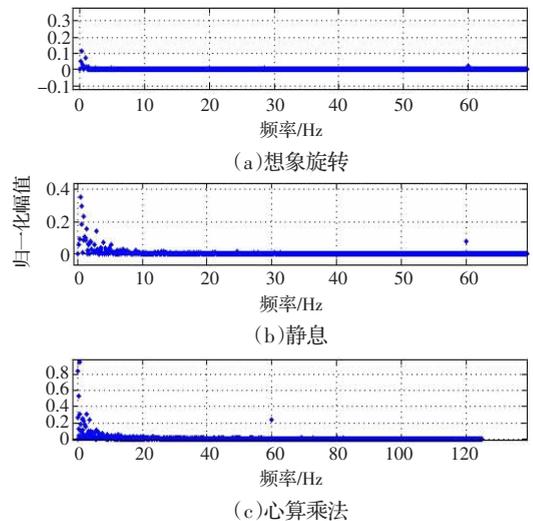


图 1 三种思维作业脑电信号的频谱图

按照 IMF 的定义,对三类信号进行 N 阶经验模态分解^[2-4], 获得 N 个 IMF 分量和剩余信号(趋势项)。原始信号可以表示为 IMF 分量和剩余信号的和,即

$$x(t)=\sum_{i=1}^n c_i+r_n \quad (2)$$

式中, $c_i, i=1, 2, 3, \dots, N$ 表示 IMF 分量, r_n 为剩余信号。对图 1 所示的三类信号的样本经 EMD 分解后得到的 IMF 分量信号如图 2 所示,其中, (a)为想象旋转, (b)为静息状态, (c)为心算乘法。

由图 2 可见, 每阶 IMF 分量含有不同频率成分, IMF 的阶数愈低,其所含高频成分愈多。在同一阶 IMF 分量上,不同类别的信号有着不同的频率成分,而且 IMF 的幅度相差很大。因此,可以考虑采用 IMF 的能量作为特征进行分类。

为了便于特征提取,选择 IMF 能量的判别熵来表征不同类别 IMF 特征的差别。设以 IMF 能量为特征的特征向量表示为:

$$X^{(i)}=(x_1^{(i)}, x_2^{(i)}, \dots, x_N^{(i)}), i=1, 2, \dots, c$$

c 为类别数, N 为特征向量的维数。设第 l 个特征向量的均值为 $u_l^{(i)}, l=1, 2, \dots, N$, 归一化均值 $P_{el}^{(i)}$ 表示为:

$$P_{el}^{(i)}=\frac{u_l^{(i)}}{\sum_{i=1}^c u_l^{(i)}} \quad (3)$$

其中 $\sum_{i=1}^c P_{el}^{(i)}=1, (i=1, 2, \dots, c)$ 。对于任意两类 s_i 和 $s_j, i, j=1, 2, \dots, c$, 第 l 个分量的判别熵定义为:

$$W(1, s_i, s_j)=V(P_{el}^{(i)}, P_{el}^{(j)}) \quad (4)$$

式中, $V(P_{el}^{(i)}, P_{el}^{(j)})$ 表示相对熵, 定义为:

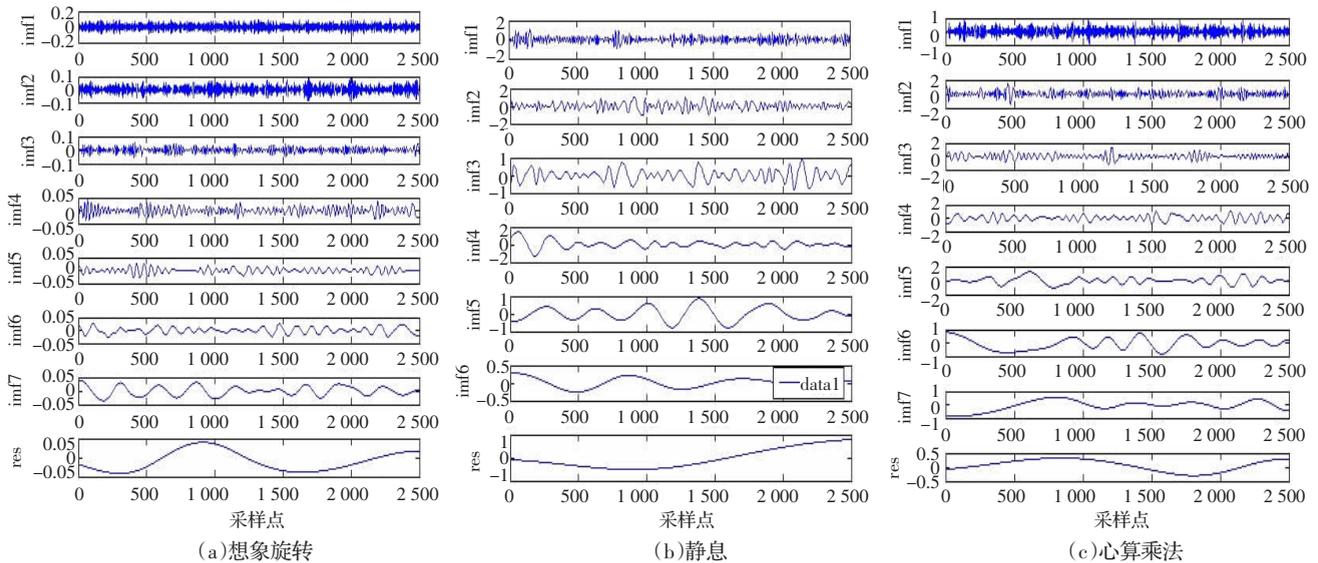


图2 三种思维信号的EMD分解图

$$V(p_{el}^{(i)}, p_{el}^{(j)}) = -\sum p_{el}^{(i)} \log[p_{el}^{(i)} p_{el}^{(j)}] \leq 0 \quad (5)$$

可以选择所有尺度的 IMF 能量的判别熵之和

$$L_c = \sum_{i=1}^c W(1, s_1, s_2) \quad (6)$$

作为类别可分性的熵度量。但在分类试验时发现, EMD 将数据分解成各个不同频率和幅度的细节分量, 它因而能对数据中细微的频率分量或幅度的差异都能体现出来。因此, 用式(6)计算同类信号不同样本之间的判别熵时, 也可能出现较小的值, 导致分类能力下降。

为此, 考虑选择部分 IMF 能量组成特征向量, 即选择那些在不同类别的样本之间有较小判别熵, 同时在同类的样本之间有较大判别熵的 IMF 能量分量进行分类器设计。

例如, 当选择分解阶数 $N=6$ 时, 第 1、2、5 阶 IMF 分量在同类样本之间有较大的判别熵, 而在不同类别样本之间的判别熵较小。由此可选

$$L_c = W_1 + W_2 + W_5 \quad (7)$$

作为熵度量, 式中下标表示 IMF 分量的阶数, 即选择第 1、2、5 阶的 IMF 能量的判别熵进行分类器的设计。

4 基于 IMF 能量熵的分类试验

基于 IMF 能量的特征提取及分类过程的流程图如图 3 所示。输入信号首先进行时域预处理, 如对信号幅度进行归一化、去直流分量等。然后对信号进行经验模态分解, 得到 IMF 分量。计算 IMF 分量的判别熵, 并从中选择特征向量, 进行分类器设计。对各类信号的样本进行分类试验, 最后得到分类结果。

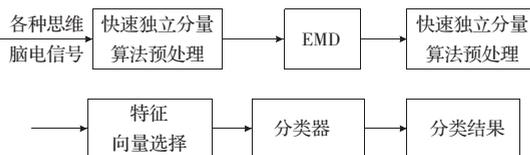


图3 基于 IMF 能量的特征提取及识别过程

对三种思维作业脑电信号进行分类试验, 首先使用快速独立分量算法对脑电信号中的眼电伪迹进行消除预处理, (取实

验者 1 的 5 次测量信号, 每次的长度为 2 500, 每次测得 6 导信号, 每类信号有 30 个样本, 每个样本的数据长度为 2 500)。然后对处理后的脑电信号作为样本, 采用 KNN 进行分类。

从 90 个样本中随机选出 40 个作为标准样本, 再从剩余的 50 个样本中随机抽取 20 个进行测试。试验时, 对样本数据进行经验模态分解, 对各种思维状态的各阶 IMF 分量采用式(6)或式(7)计算样本之间的判别熵矩阵。

分别采取欧氏距离和绝对距离作为距离尺度, 用训练集中的 40 个样本进行训练, 对测试集中的 20 个样本进行分类, 因为选择的 IMF 分量的阶数是 6, 所以 KNN 中的 K 设计为 6。

对标准样本和测试样本进行分类试验, 采用式(6)计算判别熵。对测试样本进行多次分类试验, 得到的平均分类结果如表 1 所示。采用式(7)计算判别熵, 进行分类试验, 得到分类结果如表 2 所示。

表1 标准样本和测试样本的分类实验结果

样本集	标准样本			测试样本		
	a类	b类	c类	a类	b类	c类
平均识别率/(%)	62.21	82.78	78.46	63.89	86.45	77.21

表2 采用式(7)计算判别熵得到的分类结果

类别	测试样本数	平均正确识别率/(%)			平均识别率/(%)
		a类	b类	c类	
a类	15	11	0	4	73.33
b类	15	3	10	2	66.67
c类	15	2	0	13	86.67

对比表 1 和表 2, 选择式(7)计算判别熵, 对 a 类和 c 类信号的识别率都有所提高, 但对 b 类信号的识别率有所降低, 通过频谱分析发现, a 类各样本信号的频谱之间有较大差异。这导致由式(7)计算的熵度量没能取得 b 类信号的最佳特征向量。

5 结论

从基于 IMF 能量的特征提取方法及分类试验来看, 基于 IMF 能量的特征提取方法算法非常简单, 计算量小, 而且对分解过程与试验样本选取都无特殊要求。相比其他分类方法试验的结果看, 该方法对三类脑电思维信号的分类有良好的适用性。

(下转 139 页)